

Comparison of Artificial Intelligence models used in computer games on the Unity platform

Porównanie modeli Sztucznej Inteligencji wykorzystywanych w grach komputerowych na platformie Unity

Szymon Kacprzyk*, Vladyslav Hutsenko

Department of Computer Science, Lublin University of Technology, Nadbystrzycka 36B, 20-618 Lublin, Poland

Abstract

Comparative analysis of artificial intelligence (AI) models used in computer games encompasses various approaches and techniques employed to create intelligent agents within gaming environments. Contemporary computer games utilize advanced AI systems to provide a more realistic and demanding experience for players. Three models were compared: Finite State Machine, AI Utility, and GOAP. The aim was to examine their effectiveness and applications in the context of creating intelligent agents in gaming environments. Modern games increasingly employ sophisticated AI models to ensure player immersion and maintain realism. During the research, each model was implemented, and the obtained results were subjected to detailed analysis.

Keywords: artificial intelligence; State Machine; GOAP; AI Utility

Streszczenie

Analiza porównawcza modeli sztucznej inteligencji (SI) stosowanych w grach komputerowych obejmuje różnorodne podejścia i techniki wykorzystywane do stworzenia inteligentnych agentów w środowisku gier. Współczesne gry komputerowe wykorzystują zaawansowane systemy SI w celu zapewnienia bardziej realistycznego i wymagającego doświadczenia dla graczy. Do porównania wykorzystano trzy modele: State Machine, AI Utility oraz GOAP. Celem było zbadanie ich efektywności i zastosowania w kontekście tworzenia inteligentnych agentów w środowisku gier. Współczesne gry coraz częściej wykorzystują nowoczesne modele AI, aby zapewnić graczom immersyjność oraz zachować realizm. Podczas badań, zaimplementowano każdy z modeli a uzyskane wyniki zostały poddane szczegółowej analizie.

Słowa kluczowe: sztuczna inteligencja; State Machine; GOAP; AI Utility

*Corresponding author

Email address: szymon.kacprzyk@pollub.edu.pl (S. Kacprzyk)

©Published under Creative Common License (CC BY 4.0 Int.)

1. Wstęp

W dzisiejszych czasach obserwuje się dynamiczny rozwój branży gier komputerowych, która stała się nie tylko ważnym elementem rynku rozrywki, ale także istotnym obszarem rozwoju zaawansowanych technologii takich jak sztuczna inteligencja [1-3]. Pandemia koronawirusa znacznie zwiększyła aktywność online, dzięki której gry komputerowe stały się nie tylko źródłem rozrywki, ale także czasem relaksu po ciężkim dniu pracy i rywalizacją międzynarodową co znacznie przyczyniło się do rozwoju e-sportu [4, 5].

Jednym z kluczowych obszarów, który wpływa na doznania z gier komputerowych, jest implementacja sztucznej inteligencji [6-8]. Aby sprostać wymaganiom graczy, twórcy chcą w jak największym stopniu odwzorować realny świat zarówno pod względem graficznym, jak i procesów zarządzanych przez komputer [9-11]. W tym kontekście porównanie modeli sztucznej inteligencji staje się istotnym aspektem badawczym dla deweloperów [12, 13].

Tematem badań jest porównanie i ocena trzech modeli sztucznej inteligencji, wykorzystywanych przy produkcji gier [14]. Do omawianych modeli należą: State Machine, AI Utility oraz GOAP. Każdy z nich posiada swoje wady, zalety oraz unikalne cechy, które sprawiają,

że konkretny model lepiej sprawdza się przy konkretnych sytuacjach w czasie gry [15, 16].

State Machine to klasyczny model, który opiera się na przejściach pomiędzy stanami, co pozwala na wskazanie konkretnych zachowań postaci na określone sytuacje [17]. AI Utility (ang. Artificial Intelligence Utility) skupia się na ocenie i wyborze najlepszych akcji na podstawie określonych kryteriów, a GOAP (ang. Goal-Oriented Action Planning) wykorzystuje planowanie akcji w celu osiągnięcia określonych celów [18].

Temat porównania modeli sztucznej inteligencji wykorzystywanych w grach na platformie Unity był poruszany w niewielu pracach. Celem tej pracy było nie tylko ich porównanie, lecz także zrozumienie w jakich kontekstach i sytuacjach najlepiej działa dany model. Przy obecnym dynamicznym rozwoju branży gier komputerowych analiza ta pozwala na lepsze zrozumienie aktualnych trendów oraz oczekiwań graczy [19-20].

2. Przegląd literatury

W niniejszym rozdziale przedstawione zostały istotne źródła literatury, które koncentrują się na tematach zbliżonych do tej pracy. Głównie skupiono się na pozycjach, które zawierają istotne informacje na temat wydajności

modeli sztucznej inteligencji wykorzystywanych w grach komputerowych na platformie Unity.

Rozdział literaturowy rozpoczyna się od analizy artykułów opublikowanych w czasopiśmie "Journal of Computer Science Institute". W "Analysis of selected methods of creating artificial intelligence on the example of a popular card game" autorstwa Łukasza Gałki oraz Mariusza Dzieńkowskiego, skupiono się na porównaniu pięciu algorytmów podejmujących skomplikowane decyzje w grze karcianej [21]. W zakresie analizy, kluczowym kryterium oceny skuteczności tych algorytmów jest ich optymalność, czyli zdolność do podejmowania efektywnych decyzji w zróżnicowanych sytuacjach. Algorytmy oparte na obliczeniach statystycznych wykazywały najwyższą efektywność, ale jednocześnie charakteryzowały się najdłuższym czasem wykonania. Alternatywą dla nich okazały się algorytmy oparte na sieciach neuronowych, które mimo niewielkiej utraty skuteczności, cechowały się krótszym czasem wykonania. Algorytm losowy wykazywał najniższą efektywność. Przeprowadzone porównania modeli wyraźnie wskazały, że nie występuje znacząca różnica między skutecznością sieci neuronowych a wynikami algorytmów opartych na podejściu statystycznym. W kontekście objętości kodu źródłowego i czasu implementacji, sieć neuronowa wydawała się być mniej korzystnym wyborem ze względu na znaczny nakład pracy związany z jej stworzeniem i trenowaniem. Algorytm min-max uzyskał bardzo dobre wyniki przy stosunkowo dużej skuteczności, jednak wymagał od programisty zaawansowanej wiedzy z zakresu taktyki gry.

Kolejny istotny wkład w literaturze pochodzi z pracy magisterskiej "Analiza możliwości wykorzystania algorytmów uczenia maszynowego w środowisku Unity" autorstwa Kariny Litwynenko [22]. Badanie skupia się na porównaniu efektywności dwóch algorytmów uczenia ze wzmocnieniem, tj. Proximal Policy Optimization (PPO) i Soft Actor-Critic (SAC), w kontekście gry stworzonej przy użyciu Unity i UnityML-Agents Toolkit. Ewaluacja obejmuje postęp w procesie uczenia oraz skuteczność algorytmów w różnych poziomach trudności gry. Wyniki kluczowe obejmują wyższą skuteczność PPO w porównaniu do SAC, zwłaszcza w bardziej wymagających scenariuszach gry. Stwierdzono, że proces uczenia SAC jest mniej stabilny, szczególnie w najtrudniejszym trybie gry. Dodatkowo, połączenie uczenia ze wzmocnieniem z metodą Generative Adversarial Imitation Learning (GAIL) wykazało potencjał poprawy, zwłaszcza w przypadku SAC, przy wykorzystaniu jedynie kilku minut demonstracyjnych danych. PPO uznano za bardziej wszechstronny i stabilny algorytm, łatwy w konfiguracji i mniej wrażliwy na zmiany hiperparametrów w porównaniu do SAC. Badanie sugeruje, że SAC może wykazywać lepszą skuteczność w bardziej wolnych środowiskach. Wykorzystanie Unity i ML-Agents Toolkit zostało wyróżnione za zapewnienie przyjaznej platformy dla badaczy i programistów, choć zauważono wyzwania związane z dostosowaniem hiperparametrów.

Jednym z kolejnych wartościowych pozycji jest artykuł „Machine learning for optimal blackjack counting

strategies” autorstwa S. Yakowit’a oraz M. Kollier’a, w którym autorzy poszukują najlepszej strategii sztucznej inteligencji w grze blackjack i zestawiają je z często stosowanym podejściem sztucznej inteligencji w teraźniejszych czasach [23].

Przegląd literatury kończy się analizą istotnych źródeł online, głównie w postaci stron internetowych, które dostarczają istotne informacje dotyczące używanych w pracy technologii [24, 25]. W szczególności dokumentacje, które szczegółowo opisują funkcje, udzielają wskazówek dotyczących ich praktycznego zastosowania oraz artykuły pomagające w zrozumieniu działania danego modelu i jego implementacji w projekcie.

Warto zaznaczyć, że choć dostępność artykułów porównujących modele sztucznej inteligencji wykorzystywanych w grach komputerowych na platformie Unity jest ograniczona to wymienione publikacje stanowią istotne źródło informacji. Dzięki wyżej opisanym badaniom, można zauważyć, które modele najlepiej sprawdzą się w danej sytuacji i porównać ich skuteczność. Warto zauważyć, że w niektórych sytuacjach lepsze wyniki od sztucznej inteligencji osiągnęły algorytmy. W niniejszej pracy porównane zostały trzy modele celem szczegółowej analizy ich właściwości oraz efektywności w konkretnym kontekście. Szczegółowe spojrzenie na charakterystyki modeli pozwala na wskazanie ich mocnych i słabych stron a tym samym dobór najlepszego rozwiązania dla danej sytuacji.

3. Cel i metodyka badań

Celem badania, było określenie efektywności modeli sztucznej inteligencji używanych w grach komputerowych na platformie Unity, które reprezentują różne strategie podejmowania decyzji. Są to kolejno: State Machine, GOAP oraz AI Utility.

Każdy z nich charakteryzuje się inną zasadą działania, przez co lepiej sprawdzają się w różnych sytuacjach [26]. Strategia State Machine polega na podejmowaniu decyzji określonych przez programistę po napotkaniu konkretnej sytuacji [27, 28]. Model GOAP ma zdefiniowane cele, które osiąga poprzez analizę stanu środowiska oraz zdefiniowaniu warunków, które są konieczne do wykonania danej akcji [29]. Model AI Utility działa na zasadzie wskaźnika użyteczności. Poprzez ocenę akcji stwierdza, która decyzja jest najbardziej użyteczna w danym momencie [30, 31].

Na potrzeby badań stworzono grę komputerową na platformie Unity [32, 33]. Polegała ona na rywalizacji dwóch drużyn. Każda z nich miała za zadanie wyeliminować wszystkie jednostki rywala. Porównanie modeli przeprowadzono w systemie kołowym w kilku próbach oraz podobnych warunkach, dzięki czemu uzyskano wiarygodne dane. Kolejno każdy model sterował jedną z drużyn i konkurował z drugim. Jednostki biorące udział w grze miały możliwość korzystania z bonusów pojawiających się w świecie gry takich jak dodatkowe punkty zdrowia dla poszczególnej jednostki.

Aby porównać modele, badania podzielono na dwa etapy. W pierwszym etapie wykonano trzy serie rozgrywek. W każdej serii rozegrano pięćdziesiąt rund,

w których rywalizowały ze sobą dwa modele i w ten sposób został wyznaczony zwycięzca, który najlepiej sprawdza się w tego typu grze. W pierwszej serii rywalizowały modele GOAP i State Machine, w drugiej GOAP i AI Utility, a w trzeciej State Machine i AI Utility. W drugim etapie każdemu modelowi zmierzono czas potrzebny do przejścia do nowego stanu (podjęcie nowej decyzji) w zależności od liczności jednostek jakimi operował.

W pierwszym etapie badań wprowadzone zostały miary, które dostarczyły informacje na temat działania każdego z modelu. Miary te obejmowały wskaźniki takie jak:

- liczba zachowanych jednostek,
- liczba utraconych jednostek,
- średnia liczba punktów zdrowia zachowanych jednostek,
- liczba podniesionych bonusów,
- liczba zadanych ataków,
- liczba wykonanych uników,
- czas rozgrywki,
- wynik rozgrywki (1 – zwycięstwo, 0 – porażka).

Wyniki każdej rozgrywki zostały dokładnie rejestrowane i poddane późniejszej analizie. Aby zapewnić spójność i wiarygodność wyników, każda rozgrywka toczyła się w tych samych warunkach, zasadach i scenariuszach gry.

4. Wyniki badań

W pierwszym etapie badań zostały przeprowadzone łącznie trzy serie badań po pięćdziesiąt rund. Natomiast w drugim etapie zmierzono czas potrzebny na przejście do nowego stanu, gdy dany model operował jedną, dwudziestoma pięcioma, pięćdziesięcioma oraz stoma jednostkami. W trakcie badań przeprowadzono następujące eksperymenty, w których kolejno rywalizowały ze sobą:


- AI Utility – State Machine,
- GOAP – State Machine,
- GOAP – AI Utility.

W trakcie pierwszego etapu badań, modele miały do dyspozycji jedynie trzy jednostki, co wymagało strategicznego podejścia oraz dokładnego planowania działań, aby zachować jak najwięcej punktów zdrowia oraz zwyciężyć. Badanie wykazało, że AI Utility podejmuje lepsze decyzje i zwycięża w większości przypadków. Ponadto w drugim etapie badań, uzyskano wyniki, które wskazują, że model ten potrzebuje więcej czasu od pozostałych do podjęcia decyzji. Wydłużony czas podjęcia wyboru, skutkowało lepszą skutecznością


4.1. Skuteczność modeli

W Tabelach 1-3 i na Rysunkach 1-3 przedstawiono uśrednione wyniki pomiarów z eksperymentów dla poszczególnych modeli sztucznej inteligencji. Każdy podrozdział prezentuje wyniki uzyskane dla danego modelu, w rundach z dwoma pozostałymi modelami. Są to kolejno: `alive_units` – ocalałe jednostki, `attacks` – zadane ataki, `average_hp` – średnia wartość punktów zdrowia ocalałych jednostek, `dead_units` – poległe


jednostki, `evades` – uniki, `health_picked` – podniesione bonusy zdrowia. Kolumny zawierają wyniki jedynie konkretnej drużyny, oznaczonej kolorami (GOAP – kolor niebieski, State Machine – kolor zielony, Utility AI – kolor czerwony). Na Rysunkach 1, 2 oraz 3 przedstawione zostały zwizualizowane uśrednione dane z poszczególnych trzech rozgrywek.



Rysunek 1: Porównanie średnich wyników modelu State Machine oraz GOAP w serii badań.



Rysunek 2: Porównanie średnich wyników modelu State Machine oraz AI Utility w serii badań.



Rysunek 3: Porównanie średnich wyników modelu AI Utility oraz GOAP w serii badań.

4.1.1. AI Utility

W Tabeli 1 przedstawione zostały wyniki statystyk uzyskanych przez drużynę AI Utility. Model ten cechuje się wysoką liczbą zachowanych jednostek w rozgrywkach, średnio wykonanymi dziesięcioma unikami

oraz zebranych trzema bonusami na rundę. Takie podejście skutkuje wysokim procentem zwycięstw: 98% w starciach z modelem GOAP oraz 100% w pojedynkach z modelem State Machine.

Tabela 1: Wyniki modelu AI Utility uzyskane podczas badań

	AI Utility vs GOAP	AI Utility vs State Machine
zachowane jednostki	2,24	2,72
utracone jednostki	0,76	0,28
liczba punktów zdrowia zachowanych jednostek	31,26	37,37
liczba uników	10,22	9,24
liczba ataków	32,90	27,62
liczba podniesionych bonusów	3,54	3,74
procent zwycięstw	98%	100%
czas rundy (s)	39,22	36,01

4.1.2. GOAP

W Tabeli 2 przedstawiono szczegółowe wyniki drużyny sterowanej przez model GOAP. Analizując otrzymane dane, można zauważyć, że model ten cechuje się wysoką liczbą wykonywanych ataków, która wynosi średnio trzydzieści pięć na rundę. W wyniku agresywnej strategii, model mniej skupia się na wykonywaniu uników przez co zachowane jednostki posiadają stosunkowo mało punktów zdrowia, które uśredniając wynoszą 18,8 punktów. W starciu z modelem AI Utility, model GOAP odniósł zwycięstwo jedynie w 2% pojedynków, natomiast w pojedynkach z modelem State Machine jego skuteczność była znacznie wyższa, osiągając aż 76% zwycięstw.

Tabela 2: Wyniki modelu GOAP uzyskane podczas badań

	GOAP vs AI Utility	GOAP vs State Machine
zachowane jednostki	0,04	1,50
utracone jednostki	2,96	1,50
liczba punktów zdrowia zachowanych jednostek	15,00	22,54
liczba uników	4,52	3,64
liczba ataków	35,18	41,02
liczba podniesionych bonusów	1,86	3,94
procent zwycięstw	2%	76%
czas rundy (s)	39,22	45,78

4.1.3. State Machine

W Tabeli 3 przedstawione zostały wyniki uzyskane przez State Machine. Model ten okazał się najsłabszym, co potwierdzają uzyskane dane. Nie skupiał się on na zbieraniu bonusów oraz na wykonywaniu uników przez co jednostki tej drużyny szybko zostały pokonane. W starciu z modelem AI Utility, drużyna operowana przez State Machine nie zdołała ani razu odnieść zwycięstwa w trakcie pięćdziesięciu rund, co przekłada się na odsetek zwycięstw wynoszącym 0%. Natomiast w pojedynku z modelem GOAP, State Machine odniósł zwycięstwo w 24% rund.

Tabela 3: Wyniki modelu State Machine uzyskane podczas badań

	State Machine vs GOAP	State Machine vs AI Utility
zachowane jednostki	0,34	0,00
utracone jednostki	2,66	3,00
liczba punktów zdrowia zachowanych jednostek	17,22	0,00
liczba uników	7,96	7,56
liczba ataków	34,32	29,32
liczba podniesionych bonusów	1,58	0,9
procent zwycięstw	24%	0%
czas rundy (s)	45,78	36,01

4.2. Czas podjęcia decyzji przez modele

Poza wartościami dostarczającymi informacji na temat skuteczności modeli, uzyskano także dane pozwalające na porównanie czasu potrzebnego na podjęcie decyzji przez model w zależności od ilości jednostek którymi steruje. Wyniki zaprezentowano w Tabeli 4.

Tabela 4: Porównanie czasu potrzebnego do podjęcia decyzji przez dany model

Liczba jednostek	AI Utility – czas (s)	GOAP – czas (s)	State Machine – czas (s)
1	2,3577	0,1212	0,1912
25	2,6845	0,299	0,2151
50	2,8777	0,584	0,2443
100	3,1691	0,9586	0,2942

Model AI Utility osiąga swoją skuteczność dzięki dłuższemu czasowi podejmowania decyzji dotyczących kolejnych kroków, co przekłada się na ich większą dokładność i najlepsze dostosowanie się do aktualnej sytuacji. W przeciwieństwie do tego, dwa pozostałe modele, działając nawet na stu jednostkach jednocześnie, nie przekraczają czasu jednej sekundy, co powoduje szybkie, lecz mniej dokładne decyzje, nie opierając się na otoczeniu tak szczegółowo jak w przypadku AI Utility.

5. Wnioski

Celem badań było porównanie trzech modeli sztucznej inteligencji: AI Utility, State Machine oraz GOAP, wykorzystywanych do gier komputerowych na platformie Unity w celu ułatwienia doboru odpowiedniego modelu przy produkcji gry. Główne kryteria porównawcze obejmowały skuteczność podejmowanych decyzji i ich wpływ na wygraną, a także czas potrzebny na ich dokonanie.

Przeprowadzone badania dowiodły, że każdy z modeli się różni i wykazuje inne właściwości. Zauważono, że czas podejmowania decyzji przez model decyduje o ich skuteczności i słuszności. Najsukuteczniejszym modelem okazał się model AI Utility, którego odsetek zwycięstw podczas badań wyniósł 98% i 100%. Cechuje się on najdłuższym czasem potrzebnym do podjęcia decyzji w stosunku do pozostałych modeli, co umożliwi mu dokładną analizę otoczenia i podejmowanie optymalnych decyzji w danej chwili.

Dostarczone dane sugerują, że ten model nie skupia się tylko na eliminacji przeciwników, lecz także

aktywnie poszukuje pojawiających się bonusów, takich jak punkty zdrowia, które umożliwiają zwiększenie wytrzymałości swoich jednostek. Natomiast pozostałe modele skupiają się głównie na ataku na przeciwną drużynę i wykonywaniu uników, natomiast zbieranie bonusów traktują jako opcjonalne. Analiza średniego czasu trwania pojedynków pokazuje, że rundy z udziałem modelu AI Utility były najkrótsze, co w zestawieniu z wysokim odsetkiem zwycięstw sugeruje trafność podejmowanych decyzji i świadczy o korzyściach płynących z długiego czasu ich podejmowania. W przypadku modeli GOAP oraz State Machine, decyzje były podejmowane w czasie krótszym niż sekunda, co prowadziło do niskiej skuteczności i nietrafionych działań co z kolei prowadziło do wydłużania się rundy.

Badania dowiodły, że dla gier wymagających optymalnych decyzji, model AI Utility jest najlepszym wyborem. Jego zdolność do analizy otoczenia w rzeczywistym czasie przekłada się na wysoką skuteczność i szybkie osiągnięcie celów. Natomiast modele GOAP oraz State Machine, mimo że dużo szybciej podejmują decyzje, nie nadają się do zastosowań tam, gdzie kluczowa jest strategia.

Literatura

- [1] J. P. Sousaa, R. Tavaresa, J. P. Gomesa, V. Mendonça, Review and analysis of research on Video Games and Artificial Intelligence: a look back and a step forward, *Procedia Computer Science* 204 (2022) 315-323, <https://doi.org/10.1016/j.procs.2022.08.038>.
- [2] G. N. Yannakakis, J. Togelius, Artificial Intelligence and Games, In *Genetic Programming and Evolvable Machines* 20 (2019) 143-145, <https://doi.org/10.1007/978-3-319-63519-4>.
- [3] Understanding the Role of AI in Gaming, <https://aithority.com/computer-games/understanding-the-role-of-ai-in-gaming/>, [11.07.2024].
- [4] Ch-H. Ko, J-Y. Yen, Impact of COVID-19 on gaming disorder: Monitoring and prevention, *Journal of Behavioral Addictions* 9 (2020) 187-189, <https://doi.org/10.1556/2006.2020.00040>.
- [5] F. Pallavicini, A. Pepe, F. Mantovani, The Effects of Playing Video Games on Stress, Anxiety, Depression, Loneliness, and Gaming Disorder During the Early Stages of the COVID-19 Pandemic: PRISMA Systematic Review, *Cyberpsychology, Behavior, and Social Networking* 25 (2022) 334-354, <https://doi.org/10.1089/cyber.2021.0252>.
- [6] A. El Rhalibi, K. Wai Wong, M. Price, Artificial Intelligence for Computer Games, *International Journal of Computer Games Technology* 1 (2009) 251652-251655, <https://doi.org/10.1155/2009/251652>.
- [7] F. Safadi, R. Fonteneau, D. Ernst, Artificial Intelligence in Video Games: Towards a Unified Framework, *International Journal of Computer Games Technology* 1 (2015) 271296-271321, <https://doi.org/10.1155/2015/271296>.
- [8] M. Buckland, *Programming Game AI by Example*, Jones & Bartlett Learning, Burlington, 2004.
- [9] AI in Video Games: Toward a More Intelligent Game, <https://sitn.hms.harvard.edu/>, [11.07.2024].
- [10] Artificial intelligence in gaming: Revolutionizing the player experience, <https://www.aiacceleratorinstitute.com/>, [11.07.2024].
- [11] M. Mitchell, *Artificial Intelligence: A Guide for Thinking Humans*, Farrar, Straus & Giroux, New York, 2020.
- [12] Gaming and Artificial Intelligence, <https://www.gamedesigning.org>, [11.07.2024].
- [13] S. Russell, *Human Compatible: Artificial Intelligence and the Problem of Control*, Penguin Books, London, 2019.
- [14] Q. Yin, J. Yang, K. Huang, M. Zhao, W. Ni, B. Liang, Y. Huang, S. Wu, L. Wang, AI in Human-computer Gaming: Techniques, Challenges and Opportunities, *Machine Intelligence Research* 20 (2023) 299-317, <https://doi.org/10.1007/s11633-022-1384-6>.
- [15] GameAce Ai in Game Development, <https://gameace.com/blog/ai-in-game-development>, [11.07.2024].
- [16] Artificial Intelligence in video games, <https://www.saagie.com/en/blog/artificial-intelligence-in-video-games>, [11.07.2024].
- [17] A. Andi, J. Charles, O. Pribadi, C. Juliandy, R. Robet, Game Development "Kill Corona Virus" for Education About Vaccination Using Finite State Machine and Collision Detection, *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control* 7 (2022) 317-326, <https://doi.org/10.22219/kinetik.v7i4.1470>.
- [18] Using GOAP to simplify FSMs, <https://medium.com>, [11.07.2024].
- [19] G. N. Yannakakis, J. Togelius, *Artificial Intelligence and Games*, Springer, Heidelberg, 2018.
- [20] I. Millington, J. Funge, *Artificial Intelligence for Games*, CRC Press, Boca Raton, 2006.
- [21] Ł. Gałka, M. Dzieńkowski, Analysis of selected methods of creating artificial intelligence on the example of a popular card game, *Journal of Computer Sciences* 16 (2020) 233-240, <https://doi.org/10.35784/jcsi.2194>.
- [22] K. Litwynenko, Analiza możliwości wykorzystania algorytmów uczenia maszynowego w środowisku Unity, Praca magisterska, Politechnika Lubelska, Lublin, 2021.
- [23] S. Yakowitz, M. Kollier, Machine learning for optimal blackjack counting strategies, *Journal of Statistical Planning and Inference* 33 (1992) 295-309, [https://doi.org/10.1016/0378-3758\(92\)90001-9](https://doi.org/10.1016/0378-3758(92)90001-9).
- [24] LearnUnity, <https://learn.unity.com>, [11.07.2024].
- [25] GameAiPro, <https://www.gameaiopro.com>, [11.07.2024].
- [26] A. Simonov, A. Zagarskikh, V. Fedorov, Applying Behavior characteristics to decision-making process to create believable game AI, *Procedia Computer Science* 156 (2019) 404-413, <https://doi.org/10.1016/j.procs.2019.08.222>.
- [27] State Machines in Unity (how and when to use them), <https://gamedevbeginner.com/state-machines-in-unity-how-and-when-to-use-them>, [11.07.2024].

- [28] What is a finite state machine? - Definition, <https://www.techtarget.com/whatis/definition/finite-state-machine>, [11.07.2024].
- [29] AI (FSM, Behavior Tree, GOAP, Utility AI), <https://anshuman-kumar.gitbook.io>, [11.07.2024].
- [30] J. Orkin, T. Smith, D. Roy, Behavior Compilation for AI in Games, Proceedings of the AAAI Conference on Artificial Intelligence and Interactive Digital Entertainment 6 (2010) 162-167, <https://doi.org/10.1609/aiide.v6i1.12406>.
- [31] M. Świechowski, D. Lewiński, R. Tyl, Combining Utility AI and MCTS Towards Creating Intelligent Agents in Video Games, with the Use Case of Tactical Troops: Anthracite Shift. In IEEE Symposium Series on Computational Intelligence (2021) 1-8, <https://doi.org/10.1109/SSCI50451.2021.9660170>.
- [32] S. M. Cossu, Beginning Game AI with Unity: Programming Artificial Intelligence with C#, APress, London, 2020.
- [33] Dr. E. Lavieri, Getting Started with Unity 5, Packt Publishing, Birmingham, 2015.